



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PIAUÍ
CAMPUS SENADOR HELVÍDIO NUNES DE BARROS
COORDENAÇÃO DO CURSO DE SISTEMAS DE INFORMAÇÃO
Rua Cícero Eduardo S/N – Bairro Junco – 64.600-000 – Picos –PI.
Fone (89) 3422-1087 – Fax (89) 3422-1043



**CLASSIFICAÇÃO AUTOMÁTICA DE LESÕES DE PELE EM IMAGENS MÉDICAS
UTILIZANDO MÁQUINAS DE COMITÊ**

**AUTOMATIC CLASSIFICATION OF SKIN INJURIES IN MEDICAL IMAGES
USING COMMITTEE MACHINES**

Autores: Gabriel Carvalho Moura¹, Romuere Rodrigues Veloso e Silva², Nayara Holanda de Moura³, Emerson de Sousa Silva¹, Flávio Henrique Duarte de Araújo², Alcilene Dalília de Sousa⁴

PICOS - PI

2016

¹ Graduando em Sistemas de Informação, UFPI;

² Professor(a) do curso de Sistemas de Informação, UFPI;

³ Graduado em Sistemas de Informação, UFPI;

⁴ Professora do curso de Sistemas de Informação, UFPI – Orientadora.

GABRIEL CARVALHO MOURA
ROMUERE RODRIGUES VELOSO E SILVA
NAYARA HOLANDA DE MOURA
EMERSON DE SOUSA SILVA
FLÁVIO HENRIQUE DUARTE DE ARAÚJO
ALCILENE DALÍLIA DE SOUSA

**CLASSIFICAÇÃO AUTOMÁTICA DE LESÕES DE PELE EM IMAGENS MÉDICAS
UTILIZANDO MÁQUINAS DE COMITÊ**

Trabalho de Conclusão de Curso submetido à Coordenação do Curso de Bacharelado em Sistemas de Informação da Universidade Federal do Piauí, Campus Senador Helvídio Nunes de Barros, no período 2016.1 como requisito para obtenção do título de Bacharel em Sistemas de Informação.

Orientadora: Prof. MA. Alcilene Dalília de Sousa

Co-orientador: Prof. ME. Romuere Rodrigues Veloso e Silva

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

C614

Classificação automática de lesões de pele em imagens médicas utilizando máquinas de comitê./ Gabriel Carvalho Moura [et al.]. – 2016.

CD-ROM : 4 ¾ pol. (17f.)

Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) Universidade Federal do Piauí.

Orientador (a): Profª. Ma. Alcilene Dalília de Sousa.

1. Imagens Digitais. 2. Algoritmo. 3. Lesão de Pele. I. Silva, Romue Rodrigues. II. Moura, Nayra Holanda de. III. Silva, Emerson de Sousa. IV. Araújo Flávio Henrique Duarte de. V. Título.

CDD 005.1


CLASSIFICAÇÃO AUTOMÁTICA DE LESÕES DE PELE EM IMAGENS
MÉDICAS UTILIZANDO MÁQUINAS DE COMITÊ


GABRIEL CARVALHO MOURA

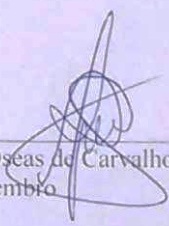
Artigo apresentado como exigência parcial para obtenção do grau de Bacharel em
Sistemas de Informação.

Data de Aprovação

Picos – PI, 14 de julho de 2016.


Prof.^a. Ma. Alcilene Dalíia de Sousa
Orientadora


Prof.^a. Ma. Patrícia Medyna Lauritzen de Lucena Drumond
Membro


Prof. Me. Antonio Oséas de Carvalho Filho
Membro

RESUMO: Nas últimas décadas os avanços tecnológicos em imagens digitais têm crescido. A procura por procedimentos que automatizam o diagnóstico auxiliado por computador em doenças vem ganhando destaque. O câncer de pele é uma doença que, cada vez mais, está aumentando sua incidência na população mundial. Para se diagnosticar lesões de pele através de imagens, é necessário segmentar, extrair características e classificar. Este trabalho tem como objetivo analisar qual algoritmo tem melhores resultados na classificação de lesões de pele. Foram testados os algoritmos de classificação *Support Vector Machine*, *K-Nearest Neighbor*, *Random Tree*, *C4.5*, *Naive Bayes*, *Random Forest*, *Radial Basis Function* e máquinas de comitê.

PALAVRAS-CHAVE: Classificação. Diagnóstico auxiliado por computador. Lesões de Pele.

ABSTRACT: In recent decades the technological advances in digital images have grown. The demand for procedures that automate the diagnosis of diseases has been gaining attention. Skin cancer is a disease that, increasingly, is increasing its incidence in the world population. To diagnose skin lesions through images, it is necessary to segment, extract features and classify. This work aims to analyze what algorithm has better results in skin lesions classification. The algorithms classification *Support Vector Machine* were tested, *K-Nearest Neighbor*, *Random Tree*, *C4.5*, *Naive Bayes*, *Random Forest*, *Radial Basis Function* and committee machine.

KEYWORDS: Classification. Computer-aided diagnoses. Skin Lesions.

1 INTRODUÇÃO

O nome câncer é atribuído a um conjunto de mais de cem doenças, onde todas têm em comum o desenvolvimento desordenado das células. O câncer de pele é uma doença de difícil detecção nas fases iniciais. Quanto mais cedo for diagnosticada a doença, maiores são as chances de cura. Para identifica-la é necessário ser observados alguns fatores, como histórico familiar da doença, o aparecimento de nevos (manchas) ou qualquer alteração na cor, forma e tamanhos em nevos já existentes. Há três tipos de cânceres de pele mais comuns: carcinoma basocelular, carcinoma epidermoide e melanoma. O melanoma é o tipo de câncer de pele com menor incidência, entretanto é o mais agressivo (INCA, 2015).

O câncer de pele ocorre com maior frequência em pessoas de pele clara devido a maior sensibilidade. A maioria das lesões ocorrem na face, que é a área mais exposta ao sol. Assim uma das formas de prevenir a doença, é a proteção dos raios solares. Por ser uma doença de difícil diagnóstico, a análise de imagens digitais vem sendo muito utilizada na sua detecção. Os dermatologistas fazem uso de técnicas e equipamentos que auxiliam no diagnóstico do câncer de pele. O dermatoscópio é utilizado para obtenção de imagens de lesões de pele, possibilitando uma avaliação clínica mais detalhada e o acompanhamento da doença (SOARES, 2008).

Para se obter um diagnóstico mais adequado da lesão é necessário serem observadas algumas características que são essenciais para sua identificação. Tais características são conhecidas como regra ABCD (Assimetria, irregularidade da Borda, variação da Cor interna e Diâmetro (BARCELOS; BOAVENTURA; SILVA, 2003). Estas servirão de entrada para os classificadores, onde irão refletir na obtenção dos resultados, classificando-as como melanoma ou não.

Esse trabalho tem como objetivo encontrar a melhor metodologia para classificação das lesões de pele, com o intuito de analisar quais classificadores possuem os melhores resultados e realizar uma nova combinação desses classificadores por meio de máquinas de comitê.

1.1 TRABALHOS RELACIONADOS

O câncer de pele, por ser uma doença bem incidente na população mundial, vem atraindo a atenção de especialistas, com o intuito de encontrar métodos que agilizem na sua detecção. Existem vários trabalhos relacionados a detecção de lesões de pele. Mais adiante estão representados alguns trabalhos nessa área.

Yuan *et al.* (2006) propuseram em seu trabalho uma detecção precoce do melanoma. Foram utilizadas 22 pares de imagens de lesões cutâneas para teste. As características foram extraídas com base na textura, onde serviu de entrada para o algoritmo de classificação SVM. As lesões foram classificadas em benigna ou maligna, onde o algoritmo utilizado demonstrou uma precisão média de 70% de acerto.

Maglogiannis (2009) em seu trabalho propôs uma classificação entre nevos displásicos, melanomas, e lesões não displásicos. O algoritmo utilizado para a realização da classificação foi o SVM, utilizando como entrada as características da regra ABCD. Foram feitas três comparações, sendo elas entre melanomas e nevos displásicos com resultados de 100% de acertos, nevos displásicos e lesões não displásicos com 76,08% de acerto e por fim, a comparação de todos os três tipos de lesões, onde obteve 77,06% de acertos.

Ruiz *et al.* (2011) sugerem em seu trabalho um sistema de apoio à decisão clínica para o diagnóstico de melanoma, utilizando como entrada um conjunto imagem da lesão de pele. Foram utilizados diferentes métodos de classificação sendo eles o: MLP, K-NN e Bayesian. Os resultados obtidos através das combinações dos classificadores resultaram em uma taxa de acertos de 87%.

Oliveira (2012) em seu trabalho utilizou um método computacional capaz de auxiliar os dermatologistas. Os resultados foram adquiridos através do algoritmo classificação Support Vector Machine (SVM), que recebeu como entrada as características de assimetria, borda, cor da regra ABCD e a característica textura. Foram feitas a classificação entre nevo e melanoma, onde obteve-se 74,36% de acerto, entre ceratose seborréica e melanoma, que obteve uma taxa de acerto de 74,33% e na classificação entre nevos e ceratose seborréica obteve-se 79,01% de acerto.

Cada classificador possui um determinado paradigma para a classificação. As máquinas de comitê foram utilizadas objetivando melhorar a capacidade de predição dos algoritmos de aprendizagem, pois não existe um único classificador que seja ótimo para todos os tipos de problemas.

2 BASE DE IMAGENS

A base de imagens utilizada é a PH². Esta base de imagens contém um total de 200 imagens dermatoscópicas, com várias variações de lesões de pele. Ela é constituída por: 80 nevos comuns, 80 nevos atípicos, e 40 melanomas, onde cada imagem possui um tamanho de 8 *bits* no sistema de cores RGB com uma resolução de 768 x 560 pixels. Todas com as suas respectivas máscaras. As imagens do banco de dados foram selecionadas levando em conta suas características de qualidade, resolução e dermatoscopia, e cada imagem foi avaliada por um dermatologista (MENDONÇA *et al.*, 2013).

Por meio da análise das imagens das lesões de pele, é possível a extração da característica, permitindo assim a identificação da lesão. A Figura 1(a) apresenta uma lesão de nevo comum, como pode ser observada a lesão tem uma cor uniforme, bordas regulares e é simétrica, e na Figura 1(d) a sua máscara. A Figura 1(b) é um nevo atípico com sua respectiva máscara na Figura 1(e), esse tipo de lesão se assemelham muito com o melanoma. Já a Figura 1(c) é um melanoma, a lesão possui bordas irregulares, é assimétrica e com variação de cores, e com a sua respectiva máscara na Figura 1(f).




Figura 1. Em (a) tem-se um nevo comum e em (d) sua máscara, em (b) tem-se um nevo atípico e em (e) sua máscara e (c) tem-se um melanoma e (f) sua respectiva máscara. Fonte: PH².

3 MÉTODO PROPOSTO

Para a realização deste trabalho foram utilizados algoritmos de aprendizado de máquina já existentes e feitas várias combinações por meio do classificador máquina de comitê, onde foram utilizadas as características de assimetria, pigmentação, pontos/glóbulos, estrias, áreas de regressão, véu azul-esbranquiçado, atributo classe e as cores: vermelho, castanho claro, branco, marrom-escuro, azul-cinza e preto extraídas por um dermatologista, objetivando a classificação das lesões de pele.

Foram realizados testes, avaliações e comparações do desempenho dos algoritmos. Os algoritmos utilizados foram o *Support Vector Machine* (SVM) (VAPNIK, 1995), *Naive Bayes* (NB) (LEWIS, 1998), *Random Forest* (RF) (BREIMAN, 2001), *Radial Basis Function* (RBF) (YUN *et al*, 2008), *Random Tree* (RT) (GEURTS; ERNST; WEHENKEL, 2006), *K-Nearest Neighbors* (K-NN) (AHA; KIBLER; ALBERT, 1991), C4.5 (QUINLAN, 1993) e três estratégias de máquina de comitê (HAYKIN, 2001), onde cada lesão é classificada como melanocítica ou não-melanocítica, podendo ser observadas na Figura 2.

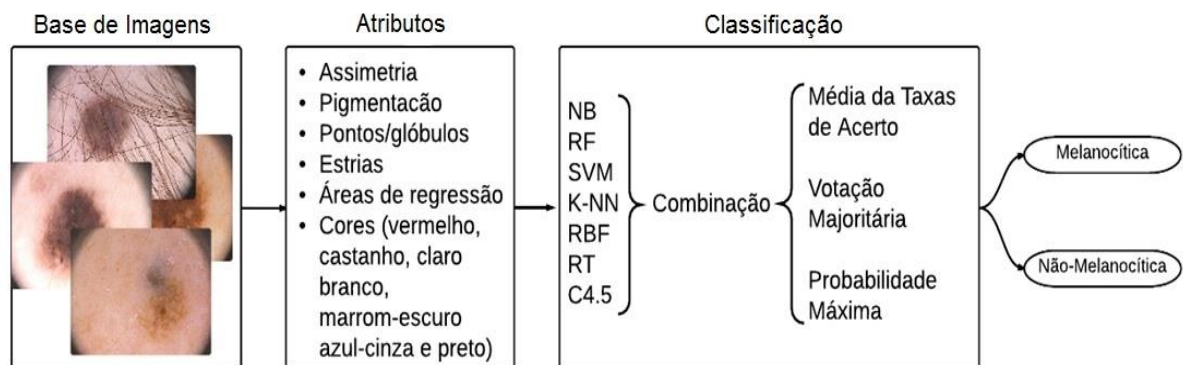


Figura 2. Fluxograma contendo os passos da metodologia proposta nesse trabalho.

3.1 APRENDIZADO DE MÁQUINA

Aprendizagem de máquina é uma subárea da inteligência artificial, esse artifício permite ao computador aprender baseado em informações prévias. Esse aprendizado pode ser de dois tipos: supervisionado ou não supervisionado (LORENA; CARVALHO, 2007).

No aprendizado supervisionado o algoritmo aprende a partir de exemplos, extrai o conhecimento necessário com o objetivo de poder generalizar para futuras entradas as saídas esperadas. Já no aprendizado não supervisionado, não existe um conjunto de exemplos

previamente informado para que a máquina possa aprender sobre o domínio do problema, ou seja, o algoritmo aprende com a ajuda de uma medida de qualidade (HAYKIN, 2001).

A classificação é um procedimento que visa o reconhecimento automático de objetos em função de determinados critérios de decisão. Com a imagem segmentada e feita a sua extração de características foram utilizados alguns algoritmos de aprendizagem de máquina. Tais algoritmos foram responsáveis por classificar a lesão como melanoma ou não.

3.1.1 *Support Vector Machine*

A *Support Vector Machine* (SVM) é um algoritmo utilizado para a classificação de padrões ou regressão linear. Ele tem como base fundamental a teoria do aprendizado estatístico e o método de minimização do risco estrutural (VAPNIK, 1998).

3.1.2 *K-Nearest Neighbors*

O classificador K-NN é um classificador em que o seu aprendizado é baseado na analogia, seu conjunto de treinamento é formado por vetores n-dimensionais e cada elemento deste conjunto representa um ponto no espaço n-dimencional. Para que seja determinada uma classe de um elemento que não pertença ao conjunto de treinamento, ele procura k elementos do conjunto de treinamento que estejam mais próximos deste elemento desconhecido (AHA; KIBLER; ALBERT, 1991).

3.1.3 *Random Tree*

O RT é um algoritmo de árvore de decisão, o seu funcionamento é baseado na escolha aleatória de atributos para cada nó da árvore, este algoritmo não realiza poda, e também não possibilita a estimativa de probabilidades de classes (GEURTS; ERNST; WEHENKEL, 2006).

3.1.4 C4.5

O Classificador C4.5 é um algoritmo que determinado qual atributo possibilita a realização de uma melhor separação entre classes, permitindo assim a geração de uma árvore univariada, ou seja, cada princípio é fundamentado em apenas um atributo (QUINLAN, 1993).

3.1.5 *Naive Bayes*

O NB é um classificador baseado em probabilidades, ele utiliza o teorema de Bayes, com suposições de independência, ou seja, os conjuntos de características da classe são

condicionalmente independentes um dos outros. Ele executa a decisão de um problema baseado na teoria da probabilidade condicional (LEWIS, 1998).

3.1.6 *Random Forest*

O RF é um conjunto de árvores de classificação. Esse algoritmo funciona de forma que cada árvore dá um voto, que irá indicar sua decisão sobre a classe do elemento. O elemento que será escolhido é a classe que possuir o maior número de votos (BREIMAN, 2001).

3.1.7 *Radial Basis Function*

O classificador RBF tem sua funcionalidade baseada na criação de mapeamentos através de combinações lineares de funções com simetria radial. Possui três tipos de parâmetros de caráter distinto: centros, variâncias (dispersões) e pesos da camada de saída (YUN *et al*, 2008).

3.1.8 Máquina de Comitê

A máquina de comitê é uma técnica de aprendizado de máquina. Essa técnica consiste no aprendizado supervisionado. Uma máquina de comitê é constituída da combinação de vários especialistas (HAYKIN, 2001). Os especialistas são algoritmos classificadores de dados, ou seja, um conjunto de algoritmos projetados para se assemelhar a especializações humanas (BARONE, 2003).

As máquinas de comitê estão subdivididas em duas categorias, estáticas e dinâmicas: As estruturas estáticas são aquelas cujo a saída é obtida através da composição de diversas respostas derivadas dos especialistas, ou seja, as respostas dos especialistas são combinadas por mecanismo que não abrangem o sinal de entrada. Já as estruturas dinâmicas dependem do sinal de entrada, ou seja, ela está diretamente envolvida na atuação dos especialistas. Neste trabalho foram utilizadas máquinas de comitê estáticas, pois elas possuem um grande número de parâmetros ajustáveis, onde os especialistas convergem para diferentes ótimos locais na superfície do erro.

As estruturas estáticas podem ser de dois tipos: média de ensemble e reforço. A média de ensemble possui como característica as saídas, onde as saídas dos especialistas são combinadas linearmente para produzir uma saída. O reforço é um algoritmo fraco de aprendizagem, que é convertido em um algoritmo que alcança uma precisão alta. Ele está subdividido em três partes, sendo elas: reforço por filtragem, reforço por sub amostragem e reforço por ponderação.

As estruturas dinâmicas estão divididas em duas partes, sendo elas: mistura de especialistas e mistura hierárquica de especialistas. Onde nas misturas de especialistas as saídas dos diferentes especialistas são não linearmente combinadas. E as misturas hierárquicas dos especialistas onde as saídas dos diferentes especialistas são não-linearmente combinadas por meio de várias redes organizadas de forma hierárquica.

3.2 VETOR DE ATRIBUTOS

O vetor de atributos foi gerado com base nos dados de cada lesão disponibilizadas na base PH² (MENDONÇA *et al.*, 2013), pois o objetivo deste trabalho é realizar testes somente com os atributos que foram extraídos pelo dermatologista. Esta base é composta pelos atributos de assimetria, pigmentação, pontos/glóbulos, estrias, áreas de regressão, véu azul-esbranquiçado, atributo classe e as cores: vermelho, castanho claro, branco, marrom-escuro, azul-cinza e preto.

No atributo de assimetria o seu valor pode variar de 0 a 2, de forma que 0 representa que a lesão é totalmente simétrica, 1 é simétrica em um dos eixos, e 2 totalmente assimétrica. A rede de pigmentos pode ter o seu valor 0 ou 1, o valor 0 representa que a lesão é típica e 1 atípica. Já os pontos/glóbulos podem ser atípicos, típicos ou ausentes, onde 0 representa uma lesão típica, 1 ausente e 2 atípica. As Estrias, áreas de regressão e véu azul-esbranquiçado, os seus valores podem ser 0 ou 1, de forma que 0 representa a sua presença e 1 a ausência. Nas cores o 0 representa a ausência da cor e o 1 a presença da mesma. E por fim o atributo classe, onde 0 indica melanoma e 1 não melanoma.

4 RESULTADOS E DISCUSSÕES

Para a obtenção dos resultados foram utilizadas as características da base PH² (MENDONÇA *et al.*, 2013), estas extraídas por um dermatologista. O método *k-fold cross validation* foi utilizado para obter os resultados (k=10). Os dados foram divididos em 10 conjuntos, sendo 9 deles utilizados para treinamento e uma para testes. Este processo é repetido 10 vezes, sendo que a cada vez uma parte é utilizada para os testes. Ao fim de todo o processo é gerado um resultado final, sendo este definido pela média de todos os resultados obtidos.

O classificador SVM foi executado utilizando uma função *kernel* de *base radial*. O RF foi limitado a profundidade máxima de árvores, sendo geradas um total de 10. O NB foi destacado empregando estimadores de classes. No classificador C4.5 foram gerados 3 nós de decisão, que especificam os testes a serem realizados. O K-NN faz a utilização dos vizinhos

mais próximos para prever a classificação, onde o valor utilizado foi $K=1$. O RT fez a utilização de 1 nó escolhido aleatoriamente para cada nó da árvore. Já o RBF utiliza 2 clusters para gerar o *K-Means*, que é um algoritmo para fornecer os parâmetros das funções de base e a máquina de comitê foi utilizada três estratégias de comitê.

4.1 METODOLOGIA DE AVALIAÇÃO DOS RESULTADOS

O desempenho obtido pelos algoritmos foi avaliado utilizando as seguintes métricas: Verdadeiro Positivo (VP), Falso Positivo (FP), Verdadeiro Negativo (VN), Falso Negativo (FN), *F-Measure* (FM), Kappa (K), área sob a curva ROC (ROC) e Acurácia (A).

A partir das quatro métricas de uma matriz de confusão, VP, FP, VN e FN torna-se possível realizar análise das outras métricas. O VP é o número de elementos não cancerígenos que foram classificados corretamente, o FP é o número de elementos não cancerígenos que foram classificados como cancerígenos, o VN é o número de elementos cancerígenos que foram corretamente classificados e o FN é o número de elementos cancerígenos que foram classificados como não cancerígenos.

O *F-Measure* tem o seu funcionamento baseando na proporção de VP em relação as suas predições negativas e positivas. Os resultados desta métrica só são melhores quando as taxas de precisão e recall são equilibradas. Seu cálculo está explicado pela Equação:

$$FM = \frac{2 * VP}{2 * VP + FN + FP}. \quad (1)$$

O K é considerado uma das métricas mais importante para a classificação, pois essa métrica representa com totalidade uma matriz de confusão, possuindo uma tabela de índices com cada precisão (Tabela 1). Ele é um coeficiente de concordância para escalas nominais que mede o relacionamento entre a concordância, além da casualidade, e a discordância esperada (ROSENFELD; FITZPATRICK-LINS, 1986). Seu cálculo está explicado pela Equação:

$$K = \frac{O_1 - O_2}{1 - O_2}, \quad (2)$$

onde,

$$O_1 = \frac{VP + VN}{VP + VN + FP + FN}, \quad (3)$$

e

$$O_2 = \frac{[(VP + FN)(VP + FP)] + [(VN + FN)(VN + FP)]}{(VP + VN + FP + FN)^2}. \quad (4)$$

Tabela 1. Níveis de exatidão do índice Kappa.

Índice Kappa (k)	Qualidade
$K \leq 0.2$	Ruim
$0.2 < K \leq 0.4$	Razoável
$0.4 < K \leq 0.6$	Bom
$0.6 < K < 0.8$	Muito Bom
$K \geq 0.8$	Excelente

A ROC nada mais é do que a representação da sensibilidade de um classificador, ou seja, a taxa de VP em função da taxa de FP. A ROC quanto maior for, mais preciso será o classificador.

A A é a porcentagem de acertos de um classificador em um conjunto de testes. Essa medida avalia o quão bem um classificador reconhece instâncias de diversas classes. Seu cálculo é explicado pela equação:

$$A = \frac{VP + VN}{VP + FP + FN + VN}. \quad (5)$$

4.2 RESULTADOS

De acordo com a Tabela 2 pode-se observar que os classificadores obtiveram bons resultados. Observa-se que o classificador RT obteve a melhor taxa de acerto com um $K=0,763$.

Tabela 2. Resultado para a Classificação das Imagens.

	VP	FP	VN	FN	FM	K	ROC	A
SVM	155	5	27	13	0,906	0,695	0,822	0,910
NB	149	11	34	6	0,917	0,746	0,962	0,915
RBF	145	15	33	7	0,894	0,680	0,936	0,890
RF	153	7	30	10	0,914	0,726	0,956	0,915
K-NN	149	11	34	6	0,917	0,746	0,962	0,915
RT	153	7	32	8	0,925	0,763	0,906	0,925
C 4.5	153	7	30	10	0,914	0,726	0,913	0,915

Com o objetivo de obter melhores resultados foram feitas seis combinações de máquina de comitê. Os algoritmos, NB, RF, SVM, K-NN, RBF, RT e C4.5 foram utilizados para compor as máquinas de comitê, de forma que a cada combinação eram utilizados 6 classificadores. Além disso, foram utilizadas três estratégias de comitê: Média da Taxa de Acerto (MTA), Votação Majoritária (VM), Probabilidade Máxima (PM).

A VM elege a opção que tem mais votos a partir de N especialistas, ou seja, destes N especialistas a saída global da máquina é a opção que mais se repetiu nos especialistas. Na MTA todos os especialistas são treinados com o mesmo conjunto de dados e podem definir entre si a escolha das condições iniciais usadas no treinamento da rede. Na PM os especialistas são treinados com conjuntos de dados inteiramente diferentes, e permite a reutilização de dados de treinamento.

Na Tabela 3 pode-se ver os resultados para a primeira combinação. Foram utilizados os classificadores NB, RF, SVM, K-NN, RT e C4.5. As estratégias MTA e VM obtiveram A e K iguais, sendo a $A=0,950$ e o $K=0,840$. Já a estratégia PM obteve um resultado menor com $A=0,905$ e um $K=0,661$.

Tabela 3. Resultado para a combinação dos classificadores: NB, RF, SVM, K-NN, RT E C4.5.

	VP	FP	VN	FN	FM	K	ROC	A
MTA	156	4	34	6	0,950	0,840	0,966	0,950
VM	156	4	34	6	0,950	0,840	0,913	0,950
PM	157	3	24	16	0,898	0,661	0,963	0,905

Na segunda combinação (Tabela 4) foram utilizados os classificadores NB, RF, SVM, K-NN, RBF e C4.5. A estratégia de VM foi a que obteve os melhores resultados possuindo uma $A=0,935$ e $K=0,798$.

Tabela 4. Resultado para a combinação dos classificadores: NB, RF, SVM, K-NN, RBF E C4.5.

	VP	FP	VN	FN	FM	K	ROC	A
MTA	154	6	32	8	0,929	0,777	0,962	0,930
VM	153	7	34	6	0,935	0,798	0,903	0,935
PM	155	5	26	14	0,900	0,675	0,954	0,905

Na terceira combinação (Tabela 5) foram utilizados os classificadores NB, RBF, SVM, K-NN, RT e C4.5. A estratégia de VM foi a que obteve os melhores resultados possuindo uma $A=0,945$ e $K=0,826$.

Tabela 5. Resultado para a combinação dos classificadores: NB, RBF, SVM, K-NN, RT E C4.5.

	VP	FP	VN	FN	FM	K	ROC	A
MTA	155	5	33	7	0,939	0,808	0,963	0,940
VM	155	5	34	6	0,945	0,826	0,909	0,945
PM	157	3	24	16	0,898	0,661	0,958	0,905

Na quarta combinação os algoritmos utilizados como entrada para a máquina de comitê foram NB, RF, RBF, K-NN, RT e C4.5. Os melhores resultados foram obtidos utilizando a técnica de VM obtendo uma $A=0,940$ e $K=0,812$ (Tabela 6).

Tabela 6. Resultado para a combinação dos classificadores: NB, RF, RBF, K-NN, RT E C4.5.

	VP	FP	VN	FN	FM	K	ROC	A
MTA	153	7	33	7	0,930	0,781	0,963	0,930
VM	154	6	34	6	0,940	0,812	0,906	0,940
PM	153	7	33	7	0,930	0,781	0,959	0,930

Na quinta combinação (Tabela 7) foram utilizados como entrada para a máquina de comitê os classificadores NB, RF, SVM, RBF, RT e C4.5. Os melhores resultados foram obtidos utilizando a técnica de VM obtendo uma $A=0,940$ e $K=0,812$.

Tabela 7. Resultado para a combinação dos classificadores: NB, RF, SVM, RBF, RT E C4.5.

	VP	FP	VN	FN	FM	K	ROC	A
MTA	154	6	32	8	0,929	0,777	0,962	0,930
VM	154	6	34	6	0,940	0,812	0,906	0,940
PM	157	3	24	16	0,898	0,661	0,957	0,905

Na sexta combinação os classificadores utilizados como entrada para a máquina de comitê foram, NB, RF, SVM, RBF, RT e K-NN. As estratégias MTA e VM conseguiram Acurácias iguais de 0,940 e K diferentes com resultados de 0,812 e 0,816 respectivamente (Tabela 8). Já a estratégia PM obteve um resultado menor que as estratégias MTA e VM, possuindo uma $A=0,905$ e $K=0,661$.

Tabela 8. Resultado para a combinação dos classificadores: NB, RF, SVM, RBF, RT E K-NN.

	VP	FP	VN	FN	FM	K	ROC	A
MTA	154	6	34	6	0,940	0,812	0,967	0,940
VM	153	7	35	5	0,941	0,816	0,916	0,940
PM	157	3	24	16	0,898	0,661	0,959	0,905

De um total de 200 imagens utilizadas para a classificação, a máquina de comitê combinando os classificadores NB, RF, SVM, K-NN, RT e C4.5 (melhor resultado), classificou corretamente 190 instâncias, constituindo em 156 não melanoma (VP) e 34 melanomas (VN). Foram rotuladas de forma errônea 10 instâncias, consistindo em 4 não melanomas classificados como melanoma (FP) e 6 melanomas classificados como não melanomas (FN). Ela obteve uma $A=0,950$ e $K=0,840$, ou seja, um resultado considerado “Excelente” de acordo com a tabela dos níveis de exatidão do K. O resultado menos significativo foi obtido pelo classificador RBF, com uma $A=0,890$ e $K=0,680$ (ROSENFELD; FITZPATRICK-LINS, 1986).

Pôde ser observado que as taxas de erros em melanomas foram bem altas em relação as não melanomas. E que as combinações de vários classificadores possibilitam melhores resultados, que os mesmos utilizados de forma isolada.

5 CONCLUSÕES E TRABALHOS FUTUROS

O câncer de pele por ser uma doença que cada vez mais vem aumentando a sua incidência, a busca por melhores resultados para o seu diagnóstico se torna essencial. Por meio da combinação dos classificadores utilizados, melhores resultados são gerados para aqueles atributos, do que classificados com apenas um classificador.

Todos os classificadores demonstraram um bom desempenho na classificação de lesões de pele. O que mais se destacou foi a máquina de comitê. Através da combinação dos algoritmos NB, RF, SVM, K-NN, RT e C4.5, utilizando as estratégias de MTA e VM. Possibilitou uma taxa de acertos maior que todos os outros classificadores utilizados de forma isolada e obtendo uma $A=0,950$ e $K=0,840$.

Os resultados obtidos se mostraram significativos, mas, podem ser melhorados. Para trabalhos futuros, pretende-se realizar novas combinações com mais classificadores e a utilização de outros parâmetros em cada um deles, para que assim melhores resultados possam

ser obtidos. Além disso, pretende-se implementar descritores clássicos da literatura com o objetivo de extrair diferentes atributos das imagens.

6 PUBLICAÇÕES

Trabalho Original:

MOURA, G. C.; SILVA, R. R. V.; MOURA, N. H.; SILVA, E. S.; ARAUJO, F. H. D. **Classificação Automática de Lesões de Pele em Imagens Médicas Utilizando Máquinas de Comitê**. Encontro Nacional de Inteligência Artificial e Computacional - ENIAC, 2015. Disponível em: <<http://www.lbd.dcc.ufmg.br/bdbcomp/servlet/Trabalho?id=23733>> . Acesso em 20 de jul de 2016.

Outros Trabalhos:

MOURA, N. H.; MOURA, G. C.; SILVA, R. R. V.; SILVA, E. S.; VERAS, R. M. S. **Classificação de Lesões de Pele Utilizando Atributos de Cor e Textura**. Workshop de Informática Médica – WIM, 2015.

MOURA, N. H.; SILVA, R. R. V.; SILVA, E. S.; MOURA, G. C. **Combinação de Componentes de Cor para Extração de Atributos em Lesões de Pele**. Escola Regional de Informática do Piauí – ERIPI, 2015.

MOURA, N. H.; SILVA, R. R. V.; SILVA, E. S.; MOURA, G. C.; VERAS, R. M. S. **Detecção Automática de Lesões de Pele em Imagens Dermatoscópicas**. Simpósio Brasileiro de Automação Inteligente – SBAI, 2015.

REFERÊNCIAS

AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-Based Learning Algorithms. **Machine Learning**, v. 6, p. 37-66, 1991.

BARCELOS, C. A. Z.; BOAVENTURA, M.; SILVA J. E. C. A well-balanced flow equation for noise removal and edge detection. **IEEE Transactions on Image Processing**, v. 12, n. 7, p. 751-763, 2003.

BREIMAN, L. Random Forests. **Machine Learning**, 45(1):5–32, 2001.

BARONE, D. Sociedades artificiais: a nova fronteira da inteligência nas máquinas. **Flores, Cecília Dias. Fundamentos dos Sistemas Especialistas**. Porto Alegre: Bookman, p. 127-154, 2003.

GEURTS, P.; ERNST, D.; WEHENKEL, L. Extremely randomized trees. **Machine learning**, v. 63, n. 1, p. 3-42, 2006.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2ª edição, Porto Alegre: Bookman, p. 900, 2001.

INSTITUTO NACIONAL DE CÂNCER (INCA). **O que é o câncer?**. Disponível em: <http://www1.inca.gov.br/conteudo_view.asp?id=322>. Acesso em: 03 jan. 2015.

LEWIS, D. D. Naive (Bayes) at forty: The independence assumption in information retrieval. In: **European conference on machine learning**. Springer Berlin Heidelberg, p. 4-15, 1998.

LORENA, A. C.; CARVALHO A. C. P. L. F. Uma Introdução às Support Vector Machines. **RITA-Revista de Informática Teórica Aplicada**, v. 14, n. 2, 2007.

MAGLOGIANNIS, I. Overview of advanced computer vision systems for skin lesions characterization. **IEEE Transactions on Information Technology in Biomedicine**, v. 13, n. 5, p. 721-733, 2009.

MENDONÇA, T.; FERREIRA, P. M.; MARQUES, J. S.; MARCAL, A. R. S.; ROZEIRA, J. PH² - A dermoscopic image database for research and benchmarking. **Annual International Conference of the IEEE Engineering in Medicine and Biology Society**, p. 5437-5440, 2013.

OLIVEIRA, R. B. **Método de detecção e classificação de lesões de pele em imagens digitais a partir do modelo Chan-Vese e máquina de vetor de suporte**, 119-f, 2012.

QUINLAN, J. R. **C4.5: Programs for Machine Learning**. San Mateo: Morgan Kaufmann Publishers, p. 302, 1993.

ROSENFELD, G. H.; FITZPATRICK-LINS, K. A. A coefficient of agreement as a measure of thematic classification accuracy. **Photogrammetric engineering and remote sensing**, v. 52, n. 2, p. 223-227, 1986.

RUIZ, D.; BERENGUER, V.; SORIANO, A.; SÁNCHEZ, B. A decision support system for the diagnosis of melanoma: A comparative approach. **Expert Systems with Applications**, v. 38, n. 12, p. 15217-15223, 2011.

SBONER, A.; ECCHER, C.; BLANZIERI, BAUER, P.; CRISTOFOLINI, M.; ZUMIANI G. A multiple classifier system for early melanoma diagnosis. **Artificial intelligence in medicine**, v. 27, n. 1, p. 29-44, 2003.

SOARES, H. B. **Análise e classificação de imagens de lesões da pele por atributos de cor, forma e textura utilizando máquina de vetor de suporte**. 2008. 180 f. Tese (Doutorado em Engenharia Elétrica e de Computação) – Centro de Tecnologia, Universidade Federal do Rio Grande do Norte, Rio Grande do Norte, 2008.

VAPNIK, N. **Statistical Learning Theory**. New York: John Wiley & Sons, 1998.

YUAN, X.; YANG, Z.; ZOURIDAKIS, G.; MULLANI, N. SVM-based texture classification and application to early melanoma detection. In: **Engineering in Medicine and Biology Society, 2006. EMBS'06. 28th Annual International Conference of the IEEE**. IEEE, 2006. p. 4775-4778.

YUN, Z.; QUAN, Z.; CAIXIN, S.; SHAOLAN, L.; YUMING, L.; YANG, S. RBF neural network and ANFIS-based short-term load forecasting approach in real-time price environment. **IEEE Transactions on power systems**, v. 23, n. 3, p. 853-858, 2008.



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA
"JOSÉ ALBANO DE MACEDO"

Identificação do Tipo de Documento

- Tese
 Dissertação
 Monografia
 Artigo

Eu, **Gabriel Carvalho Moura**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Classificação automática de lesões de pele em imagens médicas utilizando máquinas de comitê** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI 28 de Julho de 2016.

Gabriel Carvalho Moura
Assinatura